Prof.dr.sc. Salmedin Mesihović

Odsjek za historiju, Univerzitet u Sarajevu - Filozofski fakultet

7. VIII. 2026. godine

ESEJ O PROTOKOLIMA KORIŠTENJA AI (artificial inteligence, vještačke/umjetne inteligencije) U HISTORIJSKIM/ISTORIJSKIM/POVIJESNIM DISCIPLINAMA (historija, arheologija, historija umjetnosti, baštinske studije / zaštita, popularizacija, privredne aktivnosti /, etnologija, antropologija, paleolingvistika, arheogenetika).[1]

U nastavku je cjelovit akademski esej, oblikovan tako da može poslužiti kao osnova za metodološke studije ili rasprave o primjeni vještačke/umjetne inteligencije (u daljem tekstu AI) u historijskim disciplinama, podrazumijevajući sinergijske pristupe, modele rada i epistemološke granice[2].

Uvod

Razvoj AI, naročito velikih jezičkih modela (large language model - LLM), sistema u cjelini, a posebice prilikom potrage za informacijama, spajanja informacija u suvislu cjelinu, automatskog prepoznavanja teksta, govora, slike ili bilo kojeg drugog objekta, prostorne analize, statističkog modeliranja i generiranja slikea otvorio je novu etapu u proučavanju ljudske prošlosti. Historija, arheologija, historija umjetnosti, etnologija, antropologija, baštinske studije, paleolingvistika i arheogenetika pripadaju disciplinama koje se temelje na interpretaciji fragmentarnih, višeznačnih i kontekstualno i uzročno – posljednično uslovljenih izvornih podataka. Upravo zbog toga odnos ovih disciplina prema umjetnoj inteligenciji mora

[1] Pri izradi početne koncepcije, strukturiranju teksta i jezičkom oblikovanju članka korišten je AI sistem ChatGPT (GPT-5.6 Thinking), koji je razvila kompanija OpenAI, u personaliziranom izražaju pod imenom "Clara". Autor je izvršio kritičku provjeru, dopunu i konačnu redakciju cjelokupnog teksta te snosi punu odgovornost za njegov sadržaj, argumentaciju i navedene izvore.

Bibliografska napomena : OpenAI (2026), ChatGPT, GPT-5.6 Thinking, odgovor generiran 5. VIII. 2026.

[2] U historiji i arheologiji epistemologija se odnosi na pitanje kako iz izvorne građe dolazimo do znanja o prošlosti i njenom utjecaju na sadašnjost. Naprimjer, historičar dok istražuje ili samo promatra određeni izvorni narativ ili dokument ili epigrafski spomenik ne samo da se usredotočuje na sadržaj teksta i njegov slijed informacija, nego istovremeno obrađuje i njegov povijesni kontekst (vrijeme nastanka, prostor nastanka, okolnosti nastanka), vanjsku i unutarnju kritiku, *terminuse ante* i *post quem* iznesenih podataka, autora ili autore, svrhu i ciljeve sadržaja, nivo njegove tačnosti ili pristrasnosti, rukopisnu tradiciju (ili arhivsku poziciju ili nalazište i sačuvanost epigrafskog spomenika) i odnos prema drugim izvorima. Izraz epistemološke granice za AI znači granice onoga što AI može pouzdano znati, provjeriti i zaključiti. AI može pronaći obrasce i predložiti tumačenje, ali, za razliku od ljudskog znanstvenika i istraživaća, sama ne može jamčiti da je ono istinito.

biti istovremeno otvoren i kritičan. AI modeli (i u formi personaliziranih inačica) nisu samostalni znanstveni, stručni i istraživački ni subjekti ni objekti. AI ne posjeduje historijsku svijest, iskustvo terenskog, kabinetskog ili arhivskog rada, sposobnost moralne odgovornosti niti neposredno razumijevanje civiliiziranog ili kulturnog značenja. Međutim, AI može obrađivati velike količine podataka, prepoznavati pravilnosti, povezivati raspršene informacije, predlagati klasifikacije i zaključke, te ubrzavati niz tehničkih i analitičkih postupaka. Zbog toga je najprimjerenije govoriti o sinergiji znanstvenika/istraživaća i AI, a ne o zamjeni znanstvenika/istraživaća sa AI. Središnje pitanje više nije treba li humanistički znanstvenik/istraživać koristiti AI, nego pod kojim uslovima i uvjetima, u kojim fazama istraživanja i uz kakvu kontrolu njena upotreba može biti znanstveno opravdana. Upotreba AI prilikom istraživanja, analiziranja i sintetiziranja mora uvijek biti temeljena na nečelima spoznajnosti, svjesnosti, savjesnosti, kreairanja, odgovornosti, transparentnosti i obaveze ljudskog nadzora, te obraćanja pažnje na opasnosti skrivenih instrukcija u digitalnim sistemima, obradu povjerljivih informacija i interakcije s trećim stranama koje koriste AI.

I.Epistemološki položaj umjetne inteligencije

U historijskim disciplinama znanje se ne proizvodi samo jednostavnim prikupljanjem činjenica. Historijska činjenica nastaje kroz kritički odnos prema izvoru: njegovom porijeklu, kontekstu, autorstvu, izraženim ili skrivenim namjenama, namjerama i ciljevima, prenošenju, materijalnom obliku, jeziku. Historijski narativ, sačuvani ili otkriveni dokument, arheološki objekt, usmena predaja, umjetničko djelo, antropološki intervju, fragmentarni natpis, jezički relikt ili genetička informacija ne govore sami za sebe. Značenje im se pripisuje kroz metodološki obrazloženi postupak i njegovu interpretaciju.

AI, nasuprot tome, uglavnom djeluje kroz statističku obradu obrazaca u podacima. Veliki jezički model ne poznaje prošlost na isti način kao historičar. On izračunava vjerovatne veze među riječima, pojmovima i strukturama na osnovu korpusa na kojima je treniran, i korpusa pronađenih informacija. Kada odgovor AI djeluje smisleno, to ne znači nužno da je i historijski tačan. Zbog toga se mora razlikovati nekoliko nivoa:

1. Podatak predstavlja pojedinačnu zabilježenu informaciju.
2. Izvor predstavlja historijski, materijalni, vizuelni, jezički ili etnografski trag čije porijeklo i kontekst moraju biti utvrđeni.
3. Informacijski slijed nastaje organiziranjem podataka.
4. Tumačenje nastaje kritičkim povezivanjem izvora i informacijskog slijeda.
5. Znanje nastaje tek kada je tumačenje argumentirano, provjerljivo i smješteno u postojeću znanstvenu raspravu.
6. AI može biti naročito efikasan na prva tri nivoa. Može izdvajati podatke, povezivati informacije i predlagati interpretativne mogućnosti. Međutim, konačno tumačenje i pretvaranje informacijskog slijeda u znanstveno znanje moraju ostati odgovornost istraživača.

Prema tome, temeljna epistemološka zakonitost saradnje glasi: «Što je zadatak bliži mehaničkoj obradi podataka, to se veći dio posla može povjeriti AI sistemu; što je zadatak bliži historijskom značenju, uzročnosti, kulturnoj specifičnosti i moralnoj procjeni, to je nužnija neposredna kontrola stručnjaka.»

II. Osnovni modeli saradnje znanstvenika i AI

1. U instrumentalnom modelu AI je tehničko pomagalo. Istraživač određuje pitanje, metod, korpus i kriterije, dok AI izvršava ograničene zadatke kao što su :
   a) transkripcija teksta, lematizacija i morfološka analizu,
   b) obrada objekta,
   c) prepoznavanje imena, mjesta i datuma,
   d) pretvaranje podataka u tabele,
   e) pretraživanje velikih tekstualnih ili slikovnih korpusa,
   f) obrada fotografija i snimaka,
   g) izrada radnih karata i grafikona,
   h) otkrivanje ponavljajućih obrazaca,
   i) prijevodi sa drevnih i klasičnih jezika, te još uvijek „živućih“ jezika
   j) stiliziranje završnog, sintetičkog teksta,
   k) korektura, lektura i DTP.

Ovo su najsigurniji oblici upotrebe AI jer znanstvenik/istraživač zadržava potpunu metodološku inicijativu. AI ovdje ima ulogu „mikroskopa“, baze podataka, statističkog programa ili proširenog (pa i „pametnijeg“) pretraživača/browsera.

2. Kao asistivni ili dijaloški model, AI djeluje kao istraživačka konkretna pomoć Znanstvenik s njom vodi strukturirani dijalog, traži moguće hipoteze, alternativne interpretacije, bibliografske pravce, komparativne primjere i protivargumente. AI može, naprimjer, predložiti: različita objašnjenja nekog historijskog događaja, paralelne arheološke analogije i komparativne mogučnosti, moguće etimološke veze, varijante rekonstrukcije oštećenog natpisa, pitanja koja istraživač nije uključio u prvobitni model, te otkrivati slabosti postojeće argumentacije. Ovaj model može biti izuzetno produktivan, ali je i opasniji. Jezički model može formulirati uvjerljiv, stilski besprekoran, ali i potpuno netačan odgovor. Zbog toga svaki njegov prijedlog treba tretirati kao radnu hipotezu, a ne kao činjenicu. I pored ovoga, od korištenja AI kao asistivnog ili dijaloškog modela ne treba bježati.

3. Komplementarni model zasniva se na podjeli poslova prema različitim sposobnostima čovjeka i mašine/programa. AI preuzima: brzinu obrade, pretraživanje velikih korpusa, uočavanje statističkih pravilnosti, ponavljanje standardiziranih postupaka, tehničke klasifikacije, preliminarno povezivanje podataka. Znanstvenik i istraživać preuzima formuliranje problema, vrednovanje izvora, izbor relevantnog konteksta, prepoznavanje kulturne specifičnosti, interpretaciju izuzetaka, etičku procjenu, odgovornost za zaključak. Ovaj model predstavlja najuravnoteženiji odnos. AI radi ono što čovjek radi sporo, dok čovjek radi ono što AI ne može pouzdano izvršiti.

4. U kritičko-adverzarijalnom modelu, istraživač namjerno koristi AI kao oponenta. Od sistema traži da ospori njegovu hipotezu, pronađe alternativno objašnjenje, identificira logičke praznine, razdvoji dokaz od pretpostavke, predloži izvore koji bi mogli falsificirati zaključak, prepozna anakronizam ili terminološku nepreciznost. Ovaj način rada posebno je koristan jer smanjuje opasnost da AI samo potvrđuje istraživačeva početna uvjerenja. Znanstvenik ne koristi sistem kao autoritet, nego kao sredstvo intelektualnog otpora.

5. Model zatvorene istraživačke petlje je najrazvijeniji oblik saradnje. Zasniva se sljedećem slijedu : istraživačko pitanje → izbor izvora → AI obrada → ljudska provjera → korekcija modela → nova obrada → interpretacija → nezavisna provjera → objavljivanje rezultata. U ovom modelu nijedan AI rezultat ne ulazi neposredno u konačnu sintezu. Svaki prolazi kroz najmanje jednu ljudsku provjeru, a važni zaključci kroz višestruku provjeru izvora, metodologije i reproduktivnosti. Istraživanja o AI-potpomognutom historičarskom radu bi tako imala podjelu između zadataka jezičkog modela, konvencionalnih metodologija i interpretativnog rada historičara. Takvi pristupi naglašavaju da se proširivanje istraživačkog kapaciteta ne smije izjednačiti s prenošenjem autorstva ili odgovornosti na AI.

III. Primjena u pojedinim disciplinama

1. U historijskom istraživanju AI može pomoći pri obradi velikih korpusa izvornih narativnih, epigrafskih i paleografskih baza, arhivske građe, novina, korespondencije, administrativnih dokumenata, memoara i historiografije. Može prepoznavati lična imena, institucije, geografske pojmove, datume i tematske cjeline te graditi preliminarne mreže odnosa. Posebno je korisna u digitalizaciji rukopisne i štampane građe, povezivanju različitih varijanti imena, analizi političkog i administrativnog jezika, praćenju promjene značenja pojmova, identifikaciji obrazaca u velikom broju dokumenata, izradi kronologija, kartiranju korespondencije i društvenih mreža, komparativnom čitanju historiografskih interpretacija. Međutim, AI često izjednačava spominjanje sa historijskom važnošću. Slabo dokumentirane društvene grupe, marginalizirane zajednice i događaji izvan dominantnih arhivskih sistema mogu biti dodatno potisnuti. Historijski arhiv nije neutralna slika prošlosti, nego rezultat nekadašnjih odnosa moći, selekcije i očuvanja. AI treniran na takvom arhivu može samo dodatno automatizirati njegove šutnje.

U epigrafiji AI može predlagati dopune oštećenih natpisa, dataciju ili zemljopisno porijeklo na osnovu sličnosti s poznatim korpusima. Ali takav prijedlog je vjerovatnosni rezultat. Formula koja se često pojavljuje u korpusu može biti statistički najvjerovatnija, a ipak pogrešna u konkretnom natpisu. AI je pouzdanija u prijevodima epigrafskih spomenika, posebice ako su tekstovi na poznatim jezicima (na primjer latinski ili grčki). AI je pouzdanija i prilikom spajanja teksta sa eventualno postojećom ikonografijom na spomeniku i oblikom spomenika u zajednički kontekst.

2. U arheologiji se AI već koristi za analizu satelitskih snimaka, geofizičkih istraživanja, nepokretnog i pokretnog materijala, osteološkog i drugog biološkog materijala, prostornih obrazaca i tragova drevnih naselja. Razvoj dostupnih algoritama doveo je do brzog širenja mašinskog učenja u arheološkoj praksi, pa tako AI može, na primjer, i :

a) prepoznavati potencijalne lokalitete,
b) klasificirati keramičke i metalne predmete,
c) spajati fragmente ili ostatke ruševina i drugih tipova nalazišta,
d) analizirati tragove upotrebe,
e) otkrivati pravilnosti u rasporedu nalaza,
f) predlagati kronološke ili tipološke grupe,
g) modelirati kretanje ljudi kroz prostor,
h) povezivati arheološke, okolišne i klimatske podatke,
i) pomagati u digitalnoj rekonstrukciji objekata.

Ali algoritamska identifikacija lokaliteta nije isto što i arheološko otkriće. Anomalija na snimku može biti prirodna pojava, moderna intervencija ili tehnička greška. Konačna procjena zahtijeva terensko poznavanje, stratigrafski kontekst i poređenje s materijalnom kulturom. Dodatni problem predstavlja objavljivanje preciznih lokacija nezaštićenih nalazišta. AI kartiranje može nenamjerno olakšati ilegalna iskopavanja i trgovinu predmetima. Zbog toga otvorenost podataka mora biti usklađena sa zaštitom lokaliteta.

3. U historiji umjetnosti i baštinskim studijama AI se može koristiti za prepoznavanje stilskih sličnosti, pigmenata, radioničkih obrazaca, ikonografskih elemenata, kasnijih intervencija i oštećenja. U konzervatorskoj znanosti mašinsko učenje koristi se za poboljšavanje naučnih snimaka, analizu pigmenata, detekciju oštećenja, virtualnu restauraciju i procjenu buduće degradacije. Takva analiza može pomoći pri :

a) poređenju hiljada slika ili ukrasnih motiva,
b) identifikaciji radionica,
c) praćenju motiva kroz različite sredine,
d) analizi infracrvenih, rendgenskih i multispektralnih snimaka,
e) digitalnom spajanju fragmenata,
f) virtualnoj rekonstrukciji izgubljenih dijelova,
g) ranom prepoznavanju pukotina i površinskih promjena.

Ipak, stilska sličnost nije dokaz autorstva. Umjetničko djelo nije samo skup vizuelnih obilježja. Ono je i proizvod auotra/autoriaca, radionice, naručioca, kulturoloških izražaja i razloga, prezentacijea tehnika, političkog, društveno-rkonomskog i socijalnog statusa, historije recepcije i perpercije, te želja i potreba javnosti. Posebno je opasna virtualna rekonstrukcija. Digitalno dopunjavanje izgubljenog dijela može kod publike stvoriti dojam da je hipotetička rekonstrukcija jednako pouzdana kao očuvani original. Svaka rekonstrukcija zato mora jasno razlikovati dokumentirano, vjerovatno, moguće i spekulativno. Zato se preporučuje primjena AI u očuvanju, razumijevanju i dostupnosti materijalne, dokumentarne i nematerijalne baštine, ali uz ljudski nadzor, participativnost, kulturnu raznolikost, zaštitu temeljnih autorskih prava i zaštitu javnosti od potencijalnih zloupotreba.

4. Etnologija i antropologija suočavaju se sa naročito osjetljivim pitanjima jer njihovi podaci često potječu i od živih pojedinaca i zajednica koje postoje u vremenu, prostoru i okolnostima. AI može pomoći u transkripciji razgovora, kodiranju intervjua, tematskoj

analizi, poređenju narativa i organiziranju audiovizuelnog materijala. Njene prednosti uključuju:

a) ubrzanu transkripciju,
b) prepoznavanje tema u velikom broju intervjua,
c) poređenje lokalnih i regionalnih obrazaca,
d) obradu višejezičkog materijala,
e) povezivanje zvuka, slike, teksta i prostornih podataka,
f) digitalno očuvanje usmenih tradicija,
g) pomoć u dokumentiranju ugroženih kulturnih praksi.

Međutim, antropološki iskaz ne može se odvojiti od situacije u kojoj je nastao. Tišina, oklijevanje, gestikulacija, odnos povjerenja, društveni položaj sagovornika i prisutnost istraživača dio su značenja. Automatska analiza može ukloniti upravo one nijanse koje su za antropologa najvažnije. Veliki rizik predstavlja unošenje povjerljivih intervjua, fotografija, rodoslovlja ili vjerskog, religijskog, kultno-ritualnog znanja u komercijalne AI sisteme. Time istraživač može izgubiti kontrolu nad podacima ili prekršiti saglasnost ispitanika. Zato se AI sistemi ne bi trebali koristiti za povjerljive evaluacije i osjetljive podatke bez odgovarajuće zaštite. Pri istraživanju nematerijalne baštine, AI klasifikacije bez duboke saradnje sa zajednicama mogu dovesti do dekontekstualizacije kulturnog znanja. Algoritam može organizirati pjesme, obrede ili predaje prema formalnoj sličnosti, ali zanemariti odnose, zabrane i značenja poznata samo njihovim nosiocima.

5. Paleolingvistika i historijska lingvistika, odnosno proučavanje starih jezika (uključujući jezičke relikte, toponomiju, hidronimiju, oronimiju, antroponimiju), njihovih međusobnih odnosa, veza sa „živućim“ govorima, povijesnih razvitaka jezika (uključujući i narječja, dijalekte, lokalizme), rekonstrukcija jezika (na primjer protoindoeuropskog, ilirskog) jedno je od područja u kojima AI može pružiti veliku pomoć. Mašinsko učenje već se primjenjuje na drevne jezike i pisma različitih civilizacija, uključujući automatsku transliteraciju, morfološku analizu, restauraciju oštećenih tekstova i prepoznavanje obrazaca. AI može pomoći u:

a) etimologiji
b) prepoznavanju znakova i grafijskih varijanti,
c) transkripciji natpisa,
d) rekonstrukciji lakuna,
e) lematizaciji,
f) morfološkom označavanju,
g) identifikaciji posuđenica,
h) analizi glasovnih korespondencija,
i) poređenju onomastičkih obrazaca,
j) kartiranju jezičkih pojava,
k) praćenju semantičkih promjena,
l) obradi slabo dokumentiranih jezika.

Ali, AI je naročito nesiguran kod hapaksa, rijetkih imena, lokalnih jezičkih oblika i slabo dokumentiranih jezika. Modeli obično bolje rade za jezike i vrste tekstova koji su obilnije zastupljeni u podacima (na primjer znatno bolje za latinski i grčki, a slabije za venetski ili mesapski). Rezultati za nedovoljno dokumentirane dijalekte i historijske jezike zato moraju biti dodatno oprezno vrednovani. Najveća opasnost je stvaranje prividne etimologije, jer AI modeli mogu povezati fonetski slične riječi bez pravilnih glasovnih korespondencija, kronološke mogućnosti ili historijskog kontakta. U paleolingvistici AI smije predložiti vezu, ali samo stručnjak može utvrditi zadovoljava li ona komparativnu metodu.

6. Arheogenetika kao najmlađa historijska disciplina je i najviše interdisciplinarno uvezana sa drugim granama zananosti, posebno sa biologijom i njenom inačicom genetikom. Ustvari genetička istraživanja su i jedini izvor podataka za historičara sa kojim on može raditi kako bi ih doveo u informacijski slijed i povijesni kontekst. Međutim, ovo područje je i bez AI, prilično zloupotrebljavano danas iz prozaičnih rasnih, etničkih, narodnosnih, mentalitetskih razloga. Ponajviše je razlogom povećane zloupotrebe, činjenica da je jezik arheogenetike neprijemčiv za širu javnost, da se (zbog sklonosti prirodnjaka za površnom egzaktnosti) samo njihove činjenice tumače kao tačne bez uzimanja podataka iz drugih grana znanosti. Na primjer, Y-haplogrupa I2-Y3120 se u pojedinim arheološkim istraživanjima smatra kako je došla sa slavenskim migracijama početkom srednjeg vijeka, i da joj je najveća frekvencija u pojedinim dijelovima dinarskog pojasa (Hercegovina). Ali se pritom potpuno zanemaruje da je riječ o dinarskim metastazičkim populacijama za koje se preko drugih izvora zna da su jezički slavenizirane ili u kasnom srednjem vijeku ili tijekom osmanske vladavine, i da su sačuvale dosta paleobalkanskih običaja.

AI može pomoći prilagođavanjem teško razumljivog jezika arheogenetike javnosti, kako bi se izbjegla zloupotreba tumačenja arheogenetičkih istraživanja. AI može pomoći i u uvezivanju sada već golemog broja podataka u smislene cjeline. AI može pomoći i u praćenju ljudske i druge evolutivnosti na određenom prostoru kroz epohe. AI je posebice korisna u praćenju migracija, bioloških simbioza populacija i prilagođavanju pojedinca i zajednica okolišu (bilo da je riječ o novoj sredini ili prostoru koji je ubrzano promijenio zemljopisne ili klimatske forme). AI može pomoći i u interdisciplinarnom uvezivanju i zaključivanju. Ali AI može i zavesti na pogrešno zaključivanje, ako istraživać ne navede nivo istraženosti, kontekst nalaza, korištene uzorke. U suprotnom bi se moglo desiti da, na primjer, uzorak sa četiri kostura ne mora biti pravilo za čitavu širu političku, etničku, narodnosnu, plemensku zajednicu kojoj su pripadale individue čiji je osteološki materijal istraživan.

IV. Pravila i zakonitosti odgovorne saradnje

Prvo pravilo: primarni izvor ima prednost pred AI odgovorom. Nijedan odgovor AI sistema ne može zamijeniti provjeru izvornog dokumenta, predmeta, stratigrafskog zapisa, slike, arhitektonskog objekta, snimka, natpisa, svjedočenja, arheogenetičkog podatka. AI je posrednik, a ne izvor.

Drugo pravilo: AI rezultat je hipoteza dok se ne potvrdi. Svaku identifikaciju, rekonstrukciju, etimologiju, dataciju ili bibliografsku tvrdnju treba tretirati kao privremenu. Stepen jezičke uvjerljivosti nije mjera istinitosti.

Treće pravilo: odgovornost se ne može prenijeti na algoritam. AI ne može biti moralno ni akademski odgovoran za grešku. Autor publikacije odgovara za sve tvrdnje koje objavi, bez obzira na to jesu li nastale njegovim neposrednim radom ili uz pomoć AI modela. Kredibilitet znanstvene i istraživačke sinteze pripada samo autoru/autorici/autorima/autoricama, i on/ona/oni/one dobijaju ocjenu za prilikom utvrđivanja pouzdanosti, poštenja, poštovanja, odgovornosti u svezi temeljnih načela znanstvenog i istraživačkog rada.

Četvrto pravilo: upotreba AI mora biti transparentna. U radu treba navesti: koji je sistem (ili samo model ili samo personalizirana inačica modela) korišten, za koju svrhu, na kojem materijalu, u kojoj fazi istraživanja, kako su rezultati provjeravani, jesu li izlazi naknadno mijenjani, koje su verzije programa, modela ili postavki korištene kada su metodološki relevantne. Nije nužno prijavljivati svaku trivijalnu pravopisnu provjeru, ali svaka upotreba koja je utjecala na podatke, metod, interpretaciju, sliku, prijevod ili zaključak mora biti objavljena.

Peto pravilo: osjetljivi podaci ne unose se u nezaštićene sisteme. To uključuje i povjerljive arhivske dokumente, povjerljive recenzije, privatne intervjue (izuzev ako to intervjuirana osoba svjesno i slobodno dopusti), lične podatke, precizne lokacije nezaštićenih nalazišta, neobjavljene rezultate saradnika bez njihove dozvole, materijale zaštićene autorskim pravom ili ugovorom.

Šesto pravilo: korpus određuje granice rezultata. AI ne nadilazi automatski ograničenja svojih podataka. Ako su podaci zemljopisno, jezički, spolno, politički, elitistički, kulturološki ili na neki drugi način neuravnoteženi, rezultat će najčešće reproducirati tu neravnotežu. Na primjer, zbog toga što elita ostavlja iza sebe znantno više tragova u odnosu na puk, može se desiti da rezultati više izražavaju način života manjinske elite, nego većinske populacije. Na primjer, pošto je sticajem historijskim okolnosti, mnogo bolje sačuvan pisani sadržaj na trajnijim, epigrafskim materijalima nego na paleografskim materijalima, mogao bi se steći potpuno pogrešan utisak kako se u epohi klasične civilizacije mnogo više pisalo na „epigrafski“ način (kapitalnim slovima) nego na „paleografski“ način (kurzivom).

Sedmo pravilo: negativan rezultat također mora biti dokumentiran. Istraživač ne smije prikazivati samo AI prijedloge koji potvrđuju njegovu hipotezu. Potrebno je zabilježiti neuspjele klasifikacije, pogrešne identifikacije, nesigurne rezultate i slučajeve u kojima različiti modeli daju različite odgovore.

Osmo pravilo: reproduktivnost mora obuhvatiti i ljudske odluke. Nije dovoljno sačuvati programski kod ili upit. Treba dokumentirati kriterije izbora podataka; način čišćenja korpusa, uklonjene primjere, ljudske korekcije, klasifikacijske kategorije, prag pouzdanosti; razloge prihvatanja ili odbacivanja rezultata.

Deveto pravilo: interpretacija mora ostati otvorena prema izuzetku. AI prepoznaje pravilnosti, ali historijski značaj često leži u izuzetku. Jedinstveni pisani izražaj, predmet, neuobičajen ritual, rijedak jezički oblik ili odstupanje od administrativne prakse ne treba odbaciti zato što se ne uklapa u dominantni obrazac.

Deseto pravilo: zajednice nisu samo izvori podataka. U etnologiji, antropologiji i proučavanju kulturne baštine lokalne i autohtone zajednice moraju imati ulogu u određivanju načina prikupljanja, obrade, interpretacije i objavljivanja njihovog znanja. Etički okvir tu naglašava ljudska prava, dostojanstvo, kulturnu raznolikost, pravičnost i ljudski nadzor kao osnovu odgovorne primjene AI.

V. Prednosti upotrebe AI

Najvažnija prednost AI jeste proširenje istraživačkog kapaciteta. Znanstvenik može obraditi korpuse koji bi ranije zahtijevali višegodišnji timski rad, odvajanje golemih resursa i veliki utrošak vremena. AI zato omogućava :

1. Bržu obradu materijala. Hiljade stranica, slika ili kataloških zapisa mogu se preliminarno analizirati u kratkom vremenu.

2. Prepoznavanje skrivenih pravilnosti. Sistem može uočiti veze koje čovjek teško vidi u velikom broju podataka.

3. Povezivanje različitih vrsta izvora. Tekst, slika, prostor, zvuk i brojčani podaci mogu se objediniti u multimodalnu analizu.

4. Lakšu interdisciplinarnost. Historičar može povezati epigrafske, arheološke, numizmatičke, jezičke i geografske podatke.

5. Zaštitu i dostupnost baštine. Digitalizacija, klasifikacija i virtualna rekonstrukcija mogu pomoći očuvanju ugroženih predmeta, spomenika, jezika i tradicija. Tu se posebno prepoznaje mogućnost primjene AI u arhivima, bibliotekama, muzejima i zaštiti ugroženih jezika.

6. Razvoj novih istraživačkih pitanja. AI može pokazati pravilnosti koje zahtijevaju novo historijsko objašnjenje.

7. Demokratizaciju pristupa. Digitalni alati mogu približiti velike korpuse istraživačima koji nemaju pristup skupim bibliotekama, laboratorijama ili specijaliziranim bazama.

8. Jezičku podršku. AI može olakšati početno razumijevanje literature na različitim jezicima, iako prijevodi stručnih i starih tekstova moraju biti provjereni.

9. Kontrolu konzistentnosti. Sistem može prepoznati nedosljedne datume, terminologiju, bibliografske obrasce ili različite oblike istog imena.

10. Simulaciju alternativnih scenarija. U prostornim i demografskim analizama moguće je testirati više modela kretanja, naseljavanja ili distribucije.

VI. Nedostaci i opasnosti

1. Haluciniranje podataka. Generativni sistemi mogu izmisliti knjige, članke, autore, citate, arhivske signature, natpise i arheološke analogije. Problem je posebno ozbiljan zato što lažni podatak može biti predstavljen sigurnim i akademskim stilom.

2. Gubitak izvornog konteksta. Izdvajanjem rečenice, motiva ili predmeta iz cjeline AI može ukloniti društveni i materijalni kontekst. Natpis nije samo tekst, jer su i njegova lokacija, materijal, oblik slova i arheološki sloj dio izvora.

3. Automatizacija postojećih predrasuda. Ako je korpus već oblikovan kolonijalnim, nacionalnim, klasnim ili rodnim odnosima moći, AI može te odnose pretvoriti u prividno objektivne rezultate.

4. Lažna preciznost. Algoritam može dati dataciju, procentualnu vjerovatnoću ili klasifikaciju s više decimalnih mjesta. Brojčana preciznost ne znači historijsku sigurnost. Neizvjesnost modela i neizvjesnost historijskog izvora nisu ista stvar.

5. Homogenizacija interpretacije. Ako velik broj istraživača koristi iste komercijalne modele, isti korpusi i dominantne interpretacije mogu početi određivati većinu odgovora. Posljedica može biti sužavanje historiografske raznolikosti.

6. Slabljenje stručnih sposobnosti. Pretjerano oslanjanje na AI može oslabiti paleografsko čitanje, poznavanje jezika, bibliografsko istraživanje, terensko opažanje, sposobnost dugotrajnog kritičkog čitanja i logičkog zaključivanja.

7. Netransparentnost modela. Kod zatvorenih komercijalnih sistema istraživač često ne zna tačno na kojim su podacima trenirani, kako su podaci filtrirani niti zašto je dobijen određeni rezultat. To otežava znanstvenu reproduktivnost.

8. Nestabilnost rezultata. Isti upit može dati različite odgovore u različitim trenucima ili verzijama sistema. Model se može promijeniti nakon ažuriranja, što otežava ponavljanje eksperimenta.

9. Autorskopravni i etički problemi. Korpusi mogu sadržavati zaštićene publikacije, fotografije ili kulturne izraze bez odgovarajuće saglasnosti. Posebno su osjetljiva prava zajednica nad tradicionalnim znanjem.

10. Proizvodnja uvjerljivih falsifikata. Generativni sistemi mogu stvarati lažne rukopise, fotografije, rekonstrukcije, umjetnička djela i navodne snimke historijskih događaja. Historijske discipline zato će morati razvijati sve snažniju forenziku digitalnog porijekla.

VII. Potreba za korištenjem umjetne inteligencije

Upotreba AI nije apsolutna metodološka obaveza. Istraživanje manjeg korpusa, pojedinačnog predmeta ili složenog filozofskog teksta može biti kvalitetnije bez automatizirane analize. AI se ne treba koristiti samo zato što je dostupna. Ipak, potpuno odbacivanje AI postaje sve manje održivo. Digitalni korpusi rastu brže nego što ih pojedinac može pregledati. Satelitski,

laboratorijski, muzejski i arhivski podaci postaju opsežniji i složeniji. Istraživač koji ne razumije AI može postati zavisan od tehničkih stručnjaka ili nesposoban kritički procijeniti rezultate koji će sve češće ulaziti u znanstvenu literaturu. Potreba se zato ne sastoji u obavezi da svaki znanstvenik koristi AI model za pisanje. Ona se sastoji u razvoju AI pismenosti:

a) razumijevanju osnovnog načina rada sistema,
b) poznavanju njihovih ograničenja,
c) sposobnosti provjere rezultata,
d) svijesti o zaštiti podataka,
e) sposobnosti dokumentiranja metodologije,
f) prepoznavanju algoritamskih pristrasnosti,
g) razlikovanju statističke korelacije od historijskog objašnjenja.

Pravi izbor nije između „tradicionalnog znanstvenika“ i „AI znanstvenika“. Pravi izbor je između kritički obrazovanog istraživača koji razumije nove alate i istraživača koji njihove rezultate prihvata ili odbacuje bez metodološkog razumijevanja.

VIII. Predloženi protokoli rada

Odgovorna saradnja može se organizirati u deset koraka:

1. Precizno definirati istraživačko pitanje prije upotrebe AI.

2. Odrediti koje zadatke AI smije, a koje ne smije izvršavati.

3. Pripremiti i kritički opisati korpus.

4. Ukloniti ili zaštititi povjerljive i osjetljive podatke.

5. Sačuvati upite, verzije modela, postavke i datume obrade.

6. Odvojiti automatski rezultat od ljudske korekcije.

7. Provjeriti sve važne tvrdnje u primarnim izvorima i stručnoj literaturi.

8. Testirati rezultat na primjerima koji nisu korišteni pri njegovom oblikovanju.

9. Tražiti alternativna objašnjenja i negativne primjere.

10. Transparentno opisati upotrebu AI u metodološkom dijelu publikacije.

Kod posebno važnih rezultata treba primijeniti princip dvostruke nezavisne provjere. Rezultate treba provjeriti i stručnjak i druga metoda, drugi model ili nezavisni korpus.

Zaključak

Umjetna inteligencija predstavlja jedno od najmoćnijih sredstava koje su historijske discipline dobile od pojave digitalnih baza podataka. Ona može ubrzati obradu, povezati heterogene izvore, otkriti pravilnosti, pomoći u čitanju oštećenih tekstova, prepoznavanju arheoloških struktura, zaštiti umjetničkih djela i dokumentiranju ugroženih jezika i tradicija.

Međutim, AI ne razumije prošlost na ljudski i historijski način. Ona ne poznaje iskustvo vremena, gubitka, identiteta, nasilja, sjećanja, svetosti niti kulturne pripadnosti. Njena statistička sposobnost nije jednaka historijskom razumijevanju. Upravo zato povećanje njene tehničke moći mora biti praćeno povećanjem metodološke discipline.

Najplodniji model nije autonomna umjetna inteligencija, nego kritički nadzirana inteligencijska saradnja. U njoj AI proširuje vidno polje znanstvenika, ali ne određuje konačno značenje. AI predlaže, ali ne presuđuje. AI je kritički nadzirana istraživačka pomoć, a ne zamjena za znanstvenika. AI obrađuje, ali ne preuzima odgovornost. AI otkriva pravilnost, ali ne zamjenjuje objašnjenje. Temeljna zakonitost takvog rada može se sažeti u jednoj rečenici: «AI treba povjeriti ono što može ubrzati, sistematizirati i uporediti, ali ne i ono što zahtijeva konačnu procjenu istinitosti, kulturnog značenja, etičke odgovornosti i historijskog smisla.»

Budućnost historijskih disciplina neće zavisiti samo od moći algoritama. Zavisit će prije svega od toga hoće li ljudski znanstvenici uspjeti očuvati kritiku izvora, stručnu kompetenciju, transparentnost i intelektualnu odgovornost. AI može pomoći čovjeku da vidi više podataka, ali samo obrazovan i odgovoran istraživač može odlučiti šta ti podaci znače.